

불확실성 처리를 위한 효율적 덤스터 셰이퍼 증거병합 방법

이 계 성[†]

요 약

많은 전문가 시스템에서 고려되는 중요한 주제 중의 하나인 불확실성 처리에 관한 연구에는 여러 처리 기법들이 있다. 그 중 덤스터 셰이퍼 증거병합방법은 그것의 장점과 동시에 계산적 복잡성 때문에 많이 연구되고 있다. 이 논문에서는 덤스터 셰이퍼 증거병합 방법이 갖는 지수적 계산 특성을 해결하는 알고리즘을 개발한다. 두 개의 신뢰함수를 병합함에 있어 가설 집단(frame of discernment)을 두 신뢰함수에 공통되는 부분과 그 나머지로 구분해 계산 비용이 높은 덤스터 셰이퍼 병합은 공통부분인, 원래보다 축소된 가설집단에 적용해 전체 계산 효율을 높이는 효과를 가져오도록 한다. 나머지 부분에 대해서는 병합의 결과가 무관성 요소(irrelevancy factor)라 정의한 특정 상수에 의해 증감되는 선형적인 변화를 갖게되는 성질을 찾아낸다. 공유하는 요소가 없는 부분에 대해서는 병합의 결과가 간단히 이 상수의 곱에 의해 결정되므로 계산적인 효율을 증대시킬 수 있게된다.

An Efficient Dempster-Shafer Evidence Combination Scheme for Uncertainty Handling

Jae Sung Lee[†]

ABSTRACT

A number of techniques have been studied for handling uncertainty in the development of expert systems. One of techniques adopted in many expert systems is the Dempster-Shafer evidence combination scheme. This has been the main focus among others due to its favorable features and computational complexity. In this paper, we develop an algorithm to deal with the exponential complexity inherent in Dempster-Shafer evidence combination. In the evidence combination process, we divide the frame of discernment into two groups, one for those common in both belief functions and the other for the rest. A property is found that in computing new belief function for the latter group, the result of evidence combination show linear change. The irrelevancy factor is derived and used to compute the change. The main idea of the method is to reduce the size of the frame of discernment and thus exponential complexity.

1. 서 론

실세계 상황에서의 문제해결을 위한 사고는 정보의 부재로 인한 불확실성, 논리적 모순, 그리고 무지

를 포함한 불완전한 정보에 기초를 두고 최고의 의사결정을 위한 일련의 추론 처리과정이라 볼 수 있다. 상황판단 또는 의사결정의 기반이 되는 정보와 사실은 경험, 감지장치를 통한 자료, 통계적인 지식 등 여러 원천으로부터 다양한 형태를 가질 수 있다. 일반적으로 이와 같은 정보는 명확하게 표현되기가 어렵

[†] 정 회 원: 단국대학교 전자계산학과 전임강사
논문접수: 1995년 5월 11일, 심사완료: 1996년 8월 2일

고 더 나아가서는 정보 자체가 불완전하거나 모호하여 사뭇 상황판단과 결정을 오도하는 경우도 발생할 수 있다. 그러나 이와 같은 불확실한 정보 속에서 특정분야의 전문가가 이것을 능숙하게 처리할 뿐더러 매우 합리적인 해결 방안을 제시하기도 한다. 이와 같은 전문가의 처리방법을 컴퓨터에 프로그램으로 실현하여 전문가가 불확실하고 불완전한 정보를 처리하여 중요한 의사결정을 내리듯 컴퓨터로 하여금 전문가의 역할을 수행할 수 있는 복잡하고 정교한 시스템의 개발이 요구되고 있다.

불확실성 처리에 관한 연구는 전문가 시스템의 응용에서 많이 진행되어왔고 의사결정 지원시스템 등 경영분야와 공학분야 등 산업 및 연구분야에 폭넓게 사용되어 왔고 이런 분야에 사용되는 불확실한 정보의 처리방법이 다양하게 제시되기도 하였다. 다양한 처리방법은 각기 고유의 특성과 적응성을 갖기 때문에 어느 하나가 대중적으로 사용되기보다는 주어진 문제의 분석을 통해 어느 기법이 가장 적합한지를 결정하고 그에 대한 적절한 사용이 제안되어야 한다. 전문가 시스템에서 대표적으로 사용되는 불확실성 처리방법은 크게 베이지안 (Bayesian) 방법, Dempster-Shafer (DS) 기법, 확실성 요소 (Certainty Factor) 기법, 그리고 퍼지집합이론 (Fuzzy Set Theory) 등으로 나눌 수 있다. 이 연구에서는 불확실성 처리방법으로 Dempster-Shafer (DS) 이론을 선택하기로 한다.

Dempster-Shafer 기법은 많은 응용에 있어서 그 유용성이 입증된 효과적인 방법으로 인식되어 왔으나 계산적으로 매우 비효율적인 단점을 안고 있다. 가장 큰 이유는 어떤 변수(속성)에 대해 여러 개의 가설 (hypothesis)이 주어질 때 각 가설에 대한 신뢰도를 구하는 베이지안 기법 또는 확실성 요소기법과 달리 DS 기법에서는 개개의 가설은 물론 여러 개의 가설들이 모여 하나의 가설을 이루는 다중가설 (multiple hypothesis)이 허용되어 가능한 가설의 개수는 지수적 (exponential)으로 증가하게 된다. 실생활의 응용분야처럼 복잡한 문제를 해결하는 시스템에서는 이와 같이 지수적으로 불어나는 가설의 개수를 처리해야 하고 지수적인 계산적 복잡도 (computational complexity)를 개선해야하는 문제가 주요 쟁점으로 대두되고 결국 불확실성에 대한 효과적인 처리방안이 전

체 시스템의 효율성에 영향을 주어 전문가 시스템 성능을 결정짓는 주요 요소가 된다.

2. 베이지안 이론과 Dempster-Shafer 이론의 비교

DS 이론은 베이지안 이론과 마찬가지로 불확실성을 나타내는데 신뢰도 (degree of belief)를 사용한다. 그러나 DS 이론은 베이지안 이론의 여러 문제점을 제시했고 이에 대한 개선방안을 시도하였다. 요약하면,

- 하나의 확률수치가 아닌 확률구간으로 불확실성을 표현
- 불신확률 (degree of disbelief)의 표현
- 무지(ignorance)부분에 대한 표현
- 다중 가설에 대한 신뢰도

우선 첫째로 불확실성은 베이지안 이론에서처럼 하나의 수치로 나타내기보다는 신뢰구간을 지정하는 것이 보다 유효한 표현이 된다고 볼 수 있다. 어느 가설이 예상되는 확률은 그 가설에 대한 가능성 계산과 그 가설이 아닐 확률까지 고려하면 그 가설에 대한 확률구간을 구할 수 있게 된다. 확률 자체가 하나의 숫자로 표현되는 것은 불확실성에 대한 지나친 표현 양태라 생각될 수 있다. 보다 상세한 정보의 획득은 확률구간을 폭을 축소시킬 수 있을 것이다.

둘째로, 베이지안 이론에서는 어느 특정 가설 A에 대한 확률을 $P(A)$ 로 표현할 때 가설의 역 \bar{A} 에 대한 확률도 묵시적으로 가정되고 그에 대한 확률이 $1-P(A)$ 만큼 자동적으로 배정된다. DS 이론에서는 이 점에 대해 가설 A를 위한 증거가 가설 \bar{A} 를 의미해서는 안된다는 점을 강조한다.

셋째로, 베이지안 이론은 정보의 부족에서 오는 요인과 불확실성에 대한 차이가 명백하지 못한 경우가 있다. 가설집단이 A, B, C로 이루어 질 때, A를 지원하는 증거가 있을 때 그 나머지에 대한 확률, $1-P(A)$ 는 \bar{A} 에 해당하는 {B,C}를 지원하게 되고 B와 C 각각에 대해 $1-P(A)$ 의 반씩 할당이 된다. 정보의 부족으로 인한 요인, 즉, A를 지원하지 않는 부분을 나머지 가설에 대한 균등 지원으로 분배하기보다는 무지 (ignorance)로 인정하여 그 부분을 가설 집단 전체에 배당하는 것이 보다 논리적이라고 생각된다.

마지막으로 DS 이론을 가장 대표할 수 있는 특징으로 개개의 가설에 확률을 배정하는 베이지안 이론

에 비해 DS 이론은 가설 집단 (frame of discernment)의 모든 부분집합에 대해 신뢰도를 배정할 수 있도록 한다. 즉, 베이지안 이론은 모든 개별 가설들에 대해서만 확률 분포를 형성하는데 반해 DS 이론은 가설의 모든 부분집합에 대해 분포를 형성할 수 있다. 따라서 $P(A) + P(\bar{A}) \leq 1$ 의 부등식이 성립한다.

3. 계산적 효율성 관점에서의 덤스터 웨이퍼 이론의 문제점

DS 이론은 가설 집단 (frame of discernment)에 대해 가능한 모든 부분집합의 요소를 가설로 설정할 수 있다는 특징이 있다. 계산과정을 살펴보면 두 부분집합으로 이뤄진 가설 집단간의 교집합을 구하고 그에 따른 확률의 곱을 계산하는 일이 대부분의 계산과정을 차지하게 된다. 이 특징 때문에 DS 이론의 증거병합과정은 계산적 효율성이 지수적이 되는 문제점을 안고 있다 [2,7]. 예로, 가설 집합의 크기가 p일 때 최대 가능한 가설의 개수는 2^p 가 된다. 그러므로 두 개의 신뢰함수가 병합될 때 필요한 교집합 계산의 수는 2^{2p} 가 된다. 그밖에 새로이 구한 부분집합간의 포함관계 등 다양한 계산을 통해 새로운 신뢰함수가 만들어지게 된다. 복잡한 실제응용에서 처리되어야 할 많은 변수에 대한 증거병합이 계속되어지면 전체 시스템의 성능을 저하시키게 되므로 이에 대한 처리와 효율성 증대에 필요한 방안이 간구되어야 하겠다.

4. 기존의 연구결과

지수적인 계약을 제거하기 위해 여러 방안들이 제시되었는데 그 하나는 증거 병합 방법을 단일 가설에 한정하는 것이다 [1]. 또 다른 방법은 다중 가설을 허용하나 그들은 계층구조(hierarchy)의 노드에 한정 짓는 방법이다 [2,4,7]. 많은 전문가 시스템 응용에서 쓰이는 실용적인 시도로는 지식베이스를 분할하여 서로 독립적으로 운용할 수 있는 부분집합들로 나누고 각각이 문제 해결 영역과 대응하여 부분적인 문제해결 영역을 제공함으로써 가설 집단을 축소할 수 있고 따라서 그 크기를 최소화함으로써 전체적인 효율 증진을 기대할 수 있었다[8]. 이 기법은 실세계의 문제에서 일어날 수 있는 매우 크고 복잡한 추론 네트워크

에서 유용하나 전체 네트워크를 완벽하게 배타적으로 나눌 수 없기 때문에 전체적인 추론과정을 지연시키는 중복적인 증거 병합이 수반될 수 있다. 다른 시도로 Zarley [9]와 Shenoy [6]의 효율적인 알고리즘이 있다. 이 알고리즘의 주된 발상은 일반 네트워크 구조를 갖는 응용에서 가설 집단의 크기를 전체 변수 (여러 가설이 도출되는 변수 또는 속성) 집합으로 선정하는 것이 아니라 변수간 관련되는 부분 집합에 한정함으로써 그 크기를 줄였고 중간 결과를 이웃하는 연결변수 (joint variable)로 전달하는 것이다.

Zarley의 DELIEF시스템은 일반 네트워크 모델을 Markov트리로 변환하여 국부적 계산과 이웃하는 노드에 신뢰도를 전달하는 방법을 취한다. 이 네트워크에서 노드는 단일 또는 다중 가설을 나타내고 가설간의 관계는 링크로 나타낸다. 예로 A의 존재가 B의 존재를 의미한다고 할 때, 네트워크 모델은 3개의 노드 (A, B, AB)와 AB노드에서 A와 B로 가는 두 개의 링크로 구성되는 Markov 트리로 변환된다. Markov트리에서의 노드의 크기는 이웃하는 노드들의 집합이므로 전체적인 가설집단의 크기보다 매우 작음을 알 수 있다. 따라서 계산의 복잡도는 대략 2^k 로 줄어드는데 여기서 k는 Markov 트리에서 최대 노드의 크기가 된다.

Markov 네트워크에서 이웃하는 노드들은 반복적으로 결합되어 Markov트리로 전환되는데 이 결과로 만들어지는 노드는 각각의 노드보다 크지만 전체적으로 노드가 균형적으로 크기를 유지할 수 있어 가설 집합의 크기를 가장 큰 노드에 의해 결정할 수 있다. 이 트리전환 알고리즘은 결합되어 생기는 노드의 크기를 최대한 줄인다. 결합되는 두 노드를 선정할 때 두 노드 사이에 공통인 (중복되는) 요소가 많은 노드를 택하고 계산적인 복잡도는 트리의 최대크기 노드에 의해 결정된다. 그러나 네트워크의 노드간 연결이 매우 밀집된 경우 Markov트리 전환 알고리즘에 의해 생성되는 노드들의 크기가 크게 줄지 않아 효율화에 크게 도움이 되지 않는다 [3].

Shenoy의 가치기반 시스템 (Valuation-based system, VBS) [6]은 좀더 개선된 방법을 제시한다. DELIEF와 같이 일반적인 네트워크 추론 구조에서 한정된 지역에서 관련된 변수에 대해 계산하는 국소 (local) 계산과 이웃 노드로의 전달 (propagation)이 주요 알고리

즘이나 Markov tree와 같은 다른 형태로의 변환을 불필요하게 하였다. 추론 네트워크에서 각 변수에 대해 신뢰값을 계산하는데 2개의 연산을 사용한다: 결합과 한계값 계산 (marginalization). ‘융합(fusion)’이라 불리는 이 알고리즘은 결합단계에서 연결 변수 사이의 신뢰 함수를 계산하고 한계값 계산 단계에서 무관한 변수들을 제거한다. 이 두단계를 마지막 목표 변수가 남을 때까지 반복하는데 변수가 제거될 때 연결 변수들에 대해 DS 계산으로 결합되어 결과로 발생하는 신뢰함수는 제거된 변수를 제외한 부분에 대해 재계산하는 단계[5]를 거치게 된다.

위에서 조사된 바와 같이 많은 연구를 통해 DS 방법이 고유의 문제인 지수적 확장을 막는 여러 방안을 제시하였다. 효율 개선을 이룩할 수 있는 이런 방안들이 다각도로 평가되고 분석되어 왔으나 worst-case 분석에 의하면 모든 방법들이 가설 집단에 대해 지수적인 계산 비용을 피할 수 없다는 사실이다. 본 연구에서도 새로운 방법을 고안해 상한(upper bound)을 개선하려는 시도보다는 DS이론이 내포하는 고유특성을 찾아 이 성질을 이용하여 DS 신뢰병합 방법을 효율적으로 개선하고자 한다.

5. 개선된 덤스터 셰이퍼 신뢰병합 알고리즘

가능한 가설 집단은 하위 개념을 갖는 잎(leaf) 노드로부터 상위 개념을 갖는 중간노드의 형태를 갖는 트리 구조를 갖는다고 가정한다. 이런 구조를 가정하는 것은 개선된 알고리즘의 동작을 보다 잘 설명하기 위함이고 이 알고리즘은 이런 구조를 갖지 않은 경우에도 확대 적용할 수 있게된다. 위에서 소개된 방법과 마찬가지로 이 알고리즘도 두 신뢰함수 병합시 신뢰함수간 상호 공통으로 포함하는 가설을 찾아내어 이를 주요 요소 (focal element)로 사용하면 이것의 크기가 전체 가설 집단보다 작거나 같게되므로 결국 계산 효율을 증대시킬 수 있게된다.

Bel_1 을 현재까지 병합해온 신뢰함수라 하고 Bel_2 를 병합해야할 새로운 신뢰함수라 한다. m_1 과 m_2 를 각각의 기본 확률 배정 (basic probability assignment, bpa)이라 할 때, DS 신뢰 결합 방식은 새로운 bpa, $m_1 \otimes m_2$ 그리고 해당 신뢰함수는 $Bel_1 \otimes Bel_2$ 로 나타낸다. 두 신뢰함수를 정규 DS 방식으로 결합할 때 새로이

만들어진 신뢰함수를 분석한 결과 두 부분으로 나뉘는 것을 확인할 수 있다. 첫 번째 그룹은 상호 공통 요소를 포함하는 가설들이다. 이들은 정규 DS 방식을 적용할 때의 결과와 마찬가지로 비선형적인 변화를 취하는데 반해 나머지 부분인 두 번째 그룹에 대해서는 일정 상수 배의 선형적 변화만 갖는 특성이 있다는 것이 확인되었다. 따라서 DS 방식을 적용하는데 있어 이 두 부분으로 나뉘 두 번째 그룹에 대해서는 계산 비용이 비싼 DS 방식을 따르지 않고 선형적 특성에 해당되는 상수요소를 찾아 그 요소만큼 증감을 시키면 전체적인 효율 증진을 도모할 수 있게된다. 이 상수 요소를 구하기 위해 그림 1과 같은 일반 트리구조를 이용하기로 한다. 각 노드는 두 개의 첨자로 구성된다: 첫 번째 첨자는 가장 밑에 있는 레벨을 1로 하고 상향으로 올라올수록 1씩 증가한다. 두 번째 첨자는 각 레벨의 왼쪽에 위치한 노드를 1로 하고 하나씩 증가하는 순으로 번호를 매긴다.

Bel_2 는 다수의 주요 요소(focal element)로 구성될 수 있으나 문제를 간략히 하기 위해 2개의 주요 요소로 구성된다고 가정한다: n_{ik} 와 n_{il} . 계속 병합되는 신뢰함수 Bel_1 은 이들과 교집합 부분이 있는 포함적 주요 요소(inclusive focal element, IFE)와 그렇지 않은 배타적 주요 요소 (exclusive focal element, EFE)로 나뉘어 질 수 있다. $IFE = \{a_1, a_2, \dots, a_p\}$, $EFE = \{b_1, b_2, \dots, b_q\}$ EFE는 n_{ik} , n_{il} 와 공유하는 요소가 없기 때문에 그들의 n_{ik} , n_{il} 와의 교집합은 ϕ 가 된다. 각 신뢰함수의 중심(core)은 모든 주요 요소들의 집합이므로

Bel_1 의 중심 = $\{a_1, a_2, \dots, a_p, b_1, b_2, \dots, b_q\}$
 Bel_2 의 중심 = $\{n_{ik}, n_{il}\}$

여기서 $b_h \subseteq n_{ij}$, $1 < h < q$ 그리고 $j = k, l$.


〈표 1〉 신뢰함수 병합
 〈Table 1〉 Combination of belief functions

| | | | |
|--------------------------|----------------------------------|----------------------------------|------------|
| $Bel_1 \backslash Bel_2$ | IFE = $\{a_1, a_2, \dots, a_p\}$ | EFE = $\{b_1, b_2, \dots, b_q\}$ | θ_2 |
| n_{ik} | DS | ϕ | n_{ik} |
| n_{il} | | | n_{il} |
| θ_1 | IFE | EFE | 0 |

EFE의 b_k 에 대해서 새로운 $m(b_k)$ 는 다음과 같이 계산된다.

$$m(b_k) = \frac{m_1(b_k) \cdot m_2(\theta_2)}{K}$$

여기서 $1 < k < q$, $K = 1 - \sum_{x \cap y = \emptyset} m_1(x) \cdot m_2(y)$ 그리고 $m(b_k)$ 는 결과로 발생하는 확률 질량 (probability mass) 이다. 그리고



(그림 1) 계층구조
(Fig. 1) Hierarchy structure

$$\begin{aligned}
 m(EFE) &= m(b_1) + m(b_2) + \dots \\
 m_1(EFE) &= m_1(b_1) + m_1(b_2) + \dots \\
 m(EFE)_{diff} &= m(EFE) - m_1(EFE) \\
 &= \sum_{k=1, q} \{m(b_k) - m_1(b_k)\} \\
 &= \sum_{k=1, q} \left\{ \frac{m_1(b_k) \cdot m(\theta_2)}{K} - m_1(b_k) \right\} \\
 &= \left(\frac{m(\theta_2)}{K} - 1 \right) \sum_{k=1, q} m_1(b_k)
 \end{aligned}$$

$$\begin{aligned}
 \frac{m(\theta_2)}{K} &= 1 + \frac{m(EFE)_{diff}}{\sum_{k=1, q} m_1(b_k)} \\
 &= 1 + \frac{m(EFE)_{diff}}{m_1(EFE)} \\
 &= \frac{m(EFE)}{m_1(EFE)}
 \end{aligned}$$

$\frac{m(\theta_2)}{K}$ 는 무관성 요소(irrelevancy constant), C로 정

의되고 결국 이 요소가 구해지면 병합된 신뢰함수에서 b_k 에 대한 확률질량은

$$m(b_k) = m_1(b_k) \cdot C.$$

로 구해진다. C는 EFE에 대한 확률질량들로 구성됨을 알 수 있다.

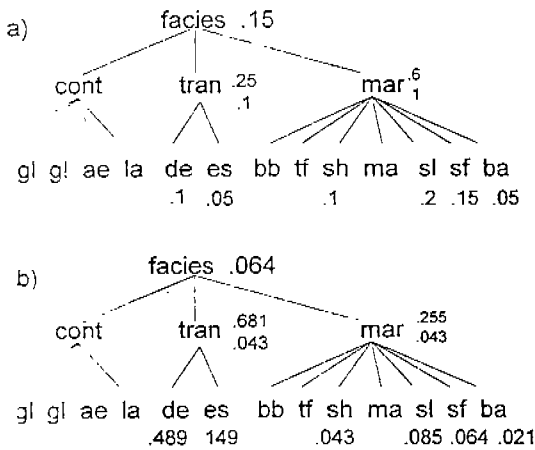
6. 알고리즘의 성능 분석 및 사용 예제

이 알고리즘은 EFE를 하나의 주요 요소 (focal element)로 취급하여 DS 계산을 수행하도록 하였다. 만일 EFE의 크기가 전체 가설 집단에 비해 매우 작다면 정규 DS계산에 비해 이득이 없음을 알 수 있다. 반면 EFE가 상대적으로 크다면 그에 해당되는 부분에 대해서는 계산적인 절약이 크게된다. 그 이유는 계산적 소용비용이 비싼 DS의 적용 분야를 해당 부분에 한정함으로 이득을 얻을 수 있기 때문이다. 따라서 이 알고리즘은 응용 영역이 명확하게 잘 정의되지 않고 해당 영역에 대한 모델이 유도되기 어려운 모호한 (fuzzy) 응용분야에 대해 효과적으로 사용될 수 있다고 생각된다. 이런 응용에서는 비록 값은 적을 지라도 여러 개의 가설에 걸쳐 신뢰값이 분포되어 있어 이들을 처리하는 것에 대한 계산비용이 상당하기 때문이다. 가설의 개수가 많아 정규 DS나 DELIEF, VBS와 같은 기법이 활용되기 어려운 분야에도 효과적으로 사용될 수 있다.

이 알고리즘을 효과적으로 운영하려면 EFE를 선정하는데 따른 계산적 손실을 최소화하도록 해야한다. 계층구조에서 주요 요소가 특정 노드로 선정되면 그것의 루트로 가는 경로상의 노드 중에서 0이 아닌 확률질량을 갖는 노드들과 그 아래에 있는 자식노드들이 IFE를 이루고 그 외에 나머지 중에서 0이 아닌 확률질량 값을 갖는 노드들은 모두 EFE에 속하게 된다.

그림 2에 보여준 facies 구조는 [4] 지질학적 특성을 파악하는데 사용되는 구조로 facies는 특성에 따라 해양적 구조 (marine, mar), 대륙적 구조 (continental, cont), 중간적 구조 (transitional, tran)로 나뉜다. 확률질량을 갖는 노드를 선별적으로 나열하면

af: alluvial fan fl: fluvial
gl: glacial ae: aeolian



(그림 2) Facies 구조
(Fig. 2) Facies structure

dc: delta es: estuarine

일 노드는 단일 가설로 이뤄져있어 확률질량과 신뢰도가 같으나 중간노드들은 다중 가설로 다중가설 자체와 그들의 부분집합에 대한 값들로 신뢰도가 계산되므로 두 개의 값을 갖는다. 노드의 우측 상단에는 신뢰도, 하단에는 그 노드의 확률 질량이다. Bel_1 은 그림 2.(a)에 나타난 바와 같이 주어지고 Bel_2 는 다음과 같이 정의된다고 한다.

$$m_2(de) = 0.6$$

$$m_2(es) = 0.2$$

Bel_1 의 pm은 IFE와 EFE로 나뉜다.

$$IFE = \{de, es, tran\}$$

$$EFE = \{sh, sl, sf, ba, mar\}$$

$$m_1(EFE) = 0.6$$

가설 집단은 $\{de, es, tran\}$ 가 되고 DS 계산에 의해

$$m(EFE) = 0.2553. \text{ 고로,}$$

$$C = \frac{0.2553}{0.6} = 0.4255$$

각 노드에 대한 변화된 $m(\cdot)$ 와 $Bel(\cdot)$ 는 그림 2.(b)에 나타난다.

$$m(sh) = 0.1 \cdot C = 0.0426$$

$$m(sl) = 0.2 \cdot C = 0.0851$$

$$m(sf) = 0.15 \cdot C = 0.0638$$

$$m(ba) = 0.05 \cdot C = 0.0213$$

$$m(mar) = 0.1 \cdot C = 0.0426$$

7. 논 의

본 연구는 델타 셰이퍼 이론에 근거를 둔 신뢰함수의 병합을 위한 효율적인 알고리즘을 개발하였다. 다중 가설을 허용하나 계층적 구조상의 노드에 한정한으로 부분집합의 개수를 제한했다. 물론 일차원의 선형적인 나열을 갖고 모든 부분 집합에 대해서 IFE와 EFE를 구분할 수 있다면 이 알고리즘의 확대 적용이 가능하다. 단, 이들을 구분하고 선별하는 것이 전체 알고리즘 수행 비용 중 어느 정도 비중을 차지할 것인지를 파악해야 한다.

이 알고리즘이 효과적으로 적용되기 위해서는 가설 집단의 크기가 크고 병합되는 두 신뢰함수간 공통 부분이 적을수록, 또 응용영역이 매우 모호하여 신뢰도가 여러 개의 가설에 걸쳐 분포될 때 이 알고리즘이 유용하게 사용될 수 있다. 지질학적 응용 분야와 같이 모델 형성이나 이론 정립 등이 지질학적 고유의 특성에 의해 매우 어렵고 모호할 경우 이 알고리즘이 효과적임을 설명하였다. 예제에서 사용한 facies 특성을 파악하는 문제를 살펴보면 17개의 가설이 계층구조를 형성하고 특정 정보 (예로, 여러 조건을 만족하는 하나의 규칙)가 의미할 수 있는 가설은 3 또는 4개 이하이다.

DELIEF나 VBS와 같은 시스템과 비교하면 이들은 증거를 포함한 증거 병합 방법인 반면 이 연구에서 개발한 알고리즘은 증거로부터 오는 정보를 근사치로 요약한 후 결론에 대해 병합하는 신뢰함수 병합이다. 규칙기반 전문가 시스템에서 많이 사용하는 방법으로 규칙의 조건부에서 가장 작은 신뢰도를 갖는 증거를 선택하여 그것과 결론부분의 (다중)가설에 할당된 신뢰도를 곱해 그 값들로 병합해야할 신뢰함수 (Bel_2)를 정의하고 이를 이용해 새로운 신뢰도를 구하는 근사방법이다. 이 방법은 DELEIF나 VBS와 같이 모든 증거를 고려한 증거병합 방법보다 효율적이다. 정확도에 있어서도 전문가의 평가, 분석 등을 통해

검증을 받았으나 이 근사방법이 정확도에 미치는 영향 등을 보다 체계적으로 연구 분석되어야 한다고 생각된다.

참 고 문 헌

[1] Barnett, J. A., "Computational methods for a mathematical theory of evidence," Proceedings of Seventh International Conference on Artificial Intelligence, 1981, pp. 868-875.

[2] Gordon, J. and Shortliffe, E. H., "A method for managing evidential reasoning in a hierarchical hypothesis space," Artificial Intelligence 26, 1985, pp. 323-357.

[3] Lee, G, Biswas, "A revised Dempster-Shafer belief combination scheme," Vanderbilt University Tech report 94-02, Vanderbilt University, Dept. of Comp. Sci., Nashville, TN, 1994

[4] Lee, G and Biswas, G., "A new version of MIDST for building PLAYMAKER: A knowledge-based system for characterizing hydrocarbon plays," Conference on AI in Petroleum Exploration and Production, Houston, Texas, 1992.

[5] Shafer, G., "A mathematical theory of evidence," Princeton University Press, 1976.

[6] Shenoy, P. P., "Valuation-based systems: A framework for managing uncertainty in expert systems," Working paper no. 226, The university of Kansas, Lawrence, KS, Mar., 1991.

[7] Shenoy, P. P. and Shafer, G., "Propagating belief functions with local computations," IEEE Expert, Fall, 1986.

[8] Wang, S. and Valtorata, M., "On the exponential growth rate of Dempster-Shafer belief functions," Applications of Artificial Intelligence X, 1992, pp. 15-24.

[9] Zarley, D., "An evidential reasoning system," Master Thesis, Dept. of Computer Science, The University of Kansas, 1988.



이 계 성

1980년 서강대학교 전자공학과 졸업 (학사)
 1982년 한국과학기술원 전산학과 (석사)
 1994년 Vanderbilt대학 전산학과 (공학박사)
 1982년~85년 경제기획원 조사통계국 전산처리관
 1994년~96년 대구대학교 전산정보학과 전임강사
 1996년~현재 단국대학교 전자계산학과 전임강사
 관심분야: 전문가 시스템, 기계학습, 지능교육시스템